

(7) 深層学習を用いたマンホール内部の不良箇所検出手法の対象拡大に向けた検討

勝村 玲音¹・及川 大輝¹・和田 雅樹¹・島原 広季¹・相原 貴明¹

¹非会員 東日本電信電話株式会社 ネットワーク事業推進本部 高度化推進部

(〒163-8019 東京都新宿区西新宿 3-19-2)

E-mail: reon.katsumura.fv@east.ntt.co.jp

現在、NTT 東日本管内では年間約 3 万個のマンホール内部の点検が行われている。現地においては 360° カメラを用いたマンホール内の撮影のみを実施し、マンホール内部の点検（良・不良判定）は、撮影した写真を用いて集約センタにて目視で行われている。私たちは目視稼働の削減に向けて画像認識の分野において成功を収めている畳み込みニューラルネットワーク（Convolutional Neural Network）を用いた AI を本写真点検業務に適用し、マンホール内の不良箇所検出の自動化を行ってきた。本取り組みではこれまでの知見を基に AI 点検項目の拡大を行い、その検出精度を検証した。

Key Words: deep learning, convolutional neural network, object detection, Infra structure

1. はじめに

NTT 東日本の重要な使命の一つが、お客様に安定したサービスを提供することである。各種サービスを提供するため、NTT 東日本は通信局舎からお客様宅を結ぶ通信ネットワークを構築しており、通信経路となるケーブル、電柱やマンホールなど、様々な設備が用いられている。サービス提供のため面的に配置される設備は、NTT 東日本の管内で、電柱が約 560 万本、マンホール約 30 万個、管路の総距離約 30 万 km に及んでいる。

これらの設備の多くは高度成長期に集中的に建設されたため、建設後 50 年以上の期間が経過しているものも多く存在し、設備の老朽化が懸念されている。こういった設備を安全に利用するためには、定期的な点検・管理業務は不可欠であり、現在多くの稼働がかかっている。また、人口減少の影響による作業員数の減少も考慮すると、今後の設備点検・管理業務の効率化は急務である。

NTT 東日本におけるマンホール設備点検は、360° カメラを用いたマンホール未入孔点検を行っており、より安全かつ簡易な現地点検が行われている。しかしながらマンホールの良・不良判定は現地にて撮影した内部写真（図-1）を用いて、集約センタにてオペレータの目視で行われており、膨大な稼働がかかっている。そこで近年、マンホール内部の不良を AI で検出する取り組みが行われている。先行研究ではマンホール内部の金物錆、露筋を対象にセマンティックセグメンテーション手法の一つ

である U-Net を用いた検討¹や、私たちが物体検出手法の一つである Mask R-CNN を用いた検討をこれまで行ってきた²。本検討では、集約センタにおけるさらなる点検稼働削減に向け、マンホール内部点検 AI の対象項目の拡大、検出精度の評価に取り組んだので報告する。



図-1 マンホール内部写真の例

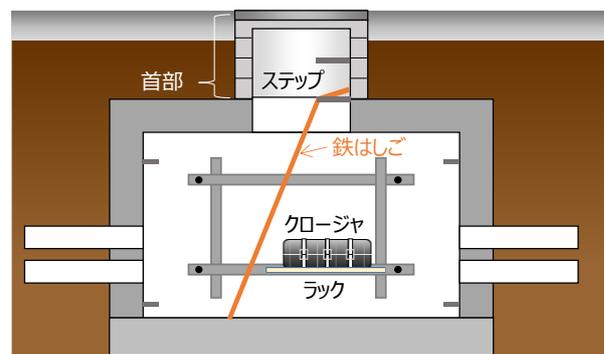


図-2 マンホール断面図

2. 使用データセット

本検討ではクロージャラック外れ、はしご錆、ステップはしご外れの3つの不良を検出対象とした。図-2に、今回の検出対象を図示したマンホール内部の断面図を示す。クロージャラック外れとはクロージャと呼ばれるケーブルの接続を行う端子台箱を支えるラックが外れている事象のことで、クロージャの脱落により、通信が遮断される危険性がある。次にはしご錆とは、マンホール内部へ入孔するためのはしごが錆びている状態であり、放置すると、入孔時の破損、落下事故につながる危険性がある。最後に、ステップはしご外れとは、はしごがマンホール首部のステップに正常に取り付けられておらず外れている、もしくは映っていない状態である。はしごが外れている状態では現地での取り付け、ステップが破損している状態ではマンホール自体の補修対応を行う。

次に、各データセットのアノテーション方法について述べる。クロージャラック外れでは、図-3の様に、(b)ラック無しクロージャ（不良）、(c)ラック付きクロージャ（健全）、(d)ラック部分（健全）の計3パターンにてアノテーションを行った。(d)ラック部分を学習させた理由は、(c)ラック付きクロージャの画像に対して誤って(b)ラック無しクロージャと検出されたときでも、同時に(d)ラック部分を検出し、健全と判断することによる誤検出の抑制を期待したためである。はしご錆については図-4の様に(a)錆びていないはしご全体（健全）、(b)錆びたはしご全体（不良）、(c)錆びていない領域をH型（健全）、(d)錆びている箇所のみをH型（不良）にそれぞれアノテーションを計4パターン行い、(a)と(b)、(c)と(d)にて2種類のデータセットを作成した。これははしご全体を学習・検出させた場合と錆の箇所に特徴を絞って学習・検出させた場合での精度比較を行うためである。ステップはしご外れに対しては、図-5の様に、(a)はしごとステップ全体（健全）、(b)はしごとステップを左右に分けてアノテーション（健全）、(c)ステップにはしごが取り付けられていない場合（不良）の計3パターンとした。これは、360°画像を用いた点検では、写真の区切り位置により、はしごが左右に分かれて撮影されることがあり、これらの画像に対しても正しく検出するためである。また、表-1に今回検証に用いた教師データ及びテストデータの画像枚数を示す。クロージャ外れについては、ラック付きのクロージャが映っている画像を健全、ラック無しのクロージャが映っている画像を不良としている。はしご錆について、錆びていないはしごが映っている画像を健全、錆びている画像が映っている画像を不良とし、ステップはしご外れでは、ステップにはしごが取り付けられている画像を健全、取り付けられていない画像は不良とそれぞれ定義している。

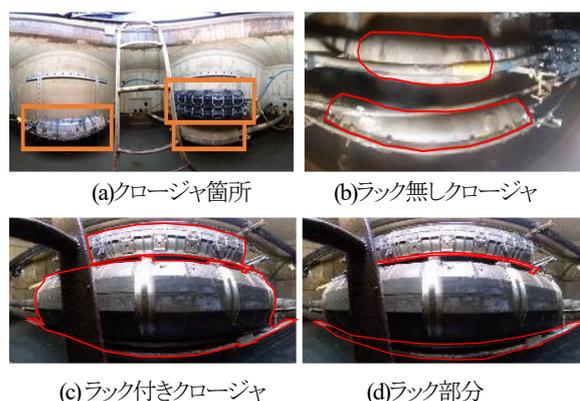


図-3 クロージャラック外れアノテーションの例

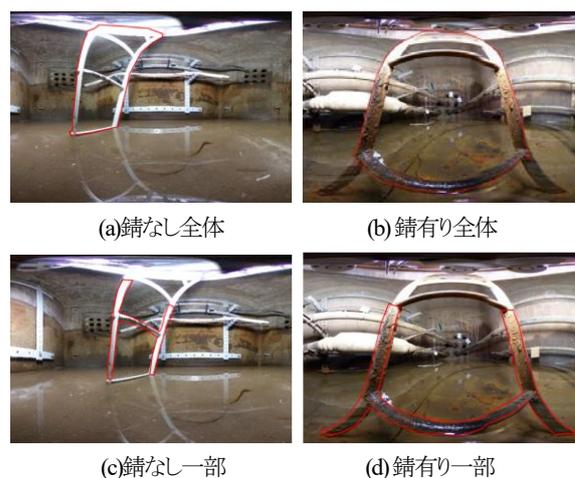


図-4 はしご錆アノテーションの例

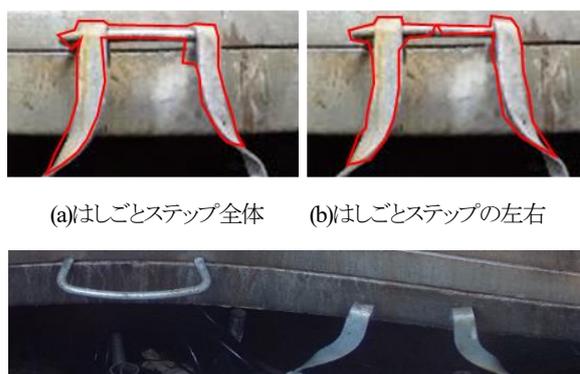


図-5 ステップはしご外れアノテーションの例

表-1 検証データセット

検出対象	教師データ	テストデータ
ケーブルラック外れ	合計 1129 枚	合計 100 枚
	健全:179 枚 不良:950 枚	健全:50 枚 不良:50 枚
はしご錆	合計 1661 枚	合計 100 枚
	健全:949 枚 不良:712 枚	健全:50 枚 不良:50 枚
ステップはしご外れ	合計 338 枚	合計 59 枚
	健全:338 枚	健全:30 枚 不良:29 枚

3. 考察

図-6、図-7、図-8 に各不良項目における検出結果を、表-2、表-3、表-4 に検出結果の混同行列を示す。本検討では、各不良項目ごとにモデルの作成を行った。また、今回は1枚のテスト画像に対し、複数の箇所が検出された場合、確信度が最も高いクラスをAIの予測結果として出力するものとした。例えば、クロージャラック外れの検出においては、クロージャラック外れのモデルを使用しており、検出候補はラック無しのクロージャ、ラック付きクロージャ、ラック部分の計3パターンが存在する。図-6(a)では検出結果としてラック部分の確信度が一番高くなるため、このテスト画像ではAIの出力結果は「ラック部分」となる。

(1)クロージャラック外れ

この時、表-2に示す混同行列より不良判定の適合率は0.82、再現率は0.81となった。図-6(c),(d)に示す例のようにすべての項目を検出しない例もあった。これはクロージャの形状や設置パターンを網羅的に学習出来ていないことが原因の一つだと考えられる。表-1に示すように、健全画像の教師データ数は179枚と、学習時に十分な数が揃っていない。また、マンホール内部の画像は地上からカメラを差し入れ、上床版側及び下床版の2つの画角から撮影されることから、これらの画角によるクロージャの映り方の違いも学習不足の原因の一つだと考えられ

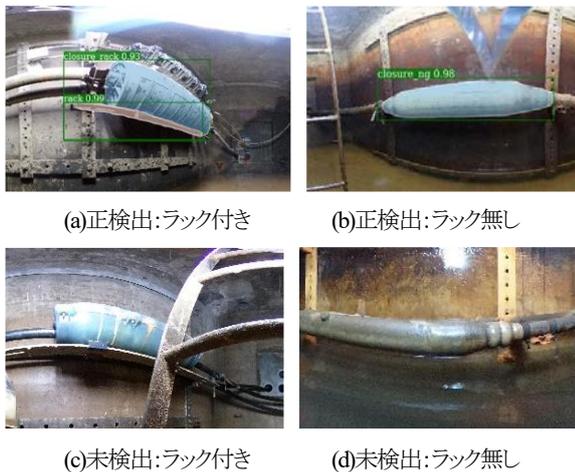


図-6 クロージャラック外れの検出結果

表-2 クロージャラック外れにおける精度

(N=100)		AI 予測	
		健全	不良
正解	健全	41	9
	不良	10	40
AI 精度		適合率	再現率
ラック外れ		0.82	0.81

る。以上から、更なる学習データの収集及び作成を行うこと、画角ごとにデータセットを分けて検証を行うことで精度の改善が見込まれる。

(2)はしご鏽

2章で示したようにデータセットを2種類作成し、表-3-1、表-3-2に示すようにはしごの一部を学習した際の不良判定の適合率は0.34、再現率は0.94となり、はしご全体を学習した際の適合率は1.0、再現率は1.0となった。はしご鏽を部分的に学習させた際には図-7(b)に示すように誤検出する例が存在した。これは、鏽びているはしごにて、一部存在している健全部分を誤検出し、確信度の比較により健全と判定してしまう場合である。部分的にアノテーションを行うと鏽の有無の他にもはしごの位置に基づいて学習がされてしまい、学習が偏ってしまう可能性がある。はしご鏽の有無を判断する場合、全体をアノテーションすることで検出率が向上すると考えられる。

(3)ステップはしご外れ

ステップはしご外れでは、2章で定義したステップはしごが正常にかかっている状態をデータセットとしてい

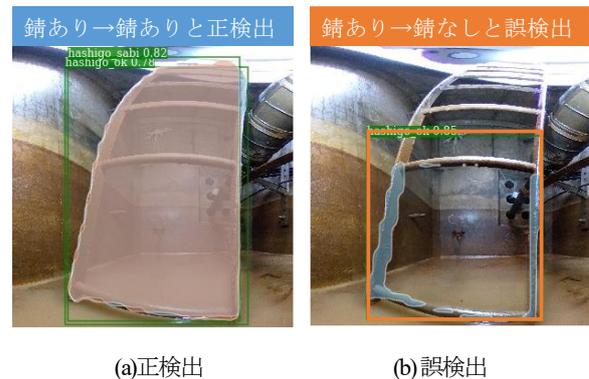


図-7 はしご鏽の検出結果

表-3-1 はしご鏽の全体学習検出時の混同行列

(N=100)		AI 予測	
		健全	不良
正解	健全	50	0
	不良	0	50
AI 精度		適合率	再現率
はしご鏽(全体)		1.0	1.0

表-3-2 はしご鏽の一部学習時の混同行列

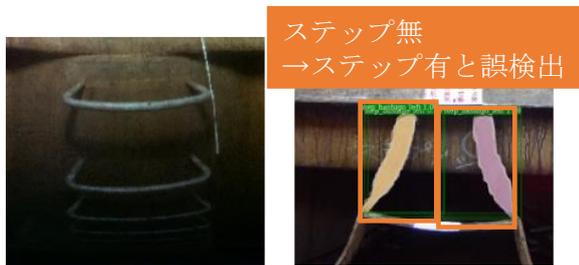
(N=100)		AI 予測	
		健全	不良
正解	健全	17	33
	不良	1	49
AI 精度		適合率	再現率
はしご鏽(一部)		0.34	0.94



(a)正検出例



(b)端のはしごを検出した例



(c)はしごがなく 未検出 (d)ステップ有と誤検出

図-8 ステップはしご外れの検出結果

表-4 ステップはしご外れにおける混同行列

(N=59)		AI 予測	
		健全	不良
正解	健全	21	8
	不良	4	26
AI精度		適合率	再現率
はしごステップ		0.84	0.72

るため3つのいずれかのクラスで検出できた場合に健全とし、未検出の場合に不良と定義した。表-4に示すように不良判定の適合率は0.84、再現率は0.72となった。図-8(b)のようにはしごが左右に分割されて映っている画像に対しても、正しく検出しており、左右分けたデータセットの使用により精度が向上することを確認した。図-8

(c)に示すように、はしごが映っていない画像の場合にはステップを誤って検出することはなかった。

しかし、図-8(d)のようにはしごがステップに掛かっておらず、はしご本体のみが映っている画像に対して誤検出する例があった。左右に区切って学習させたことにより、ステップ部分の学習が不十分となりステップの特徴を上手く学習できなかったことが原因と考えられる。今回作成したモデルは過検出する傾向（適合率が低く、再現率が高い）があることを確認した。

本検討では、ステップとはしごをまとめてアノテーションさせることで学習データの作成を行った。しかし上述のようにはしごがステップに掛かっている状態を学習することが難しく適合率が低い結果となった。

4. おわりに

マンホール内部の不良箇所検出に Mask R-CNN を用いた AI の作成、評価を行った。本検討ではクロージャラック外れ、はしご錆、ステップはしご外れの各不良項目に対し学習データの作成、不良判定結果を評価した。学習データパターン不足による学習不足や、教師データ作成時のアノテーション領域の違いによる不良判定精度の差などの知見を得ることができた。今後は、これらの知見を元に学習データを精査することにより、更なる精度の検証を進めていく。

参考文献

- 1) 渡邊一旭, 内堀大輔, 中川 雅史, 荒武 淳: U-net を用いた深層学習による通信用マンホール内の鉄筋露出および金物腐食検出技術, 2020 年度土木学会全国大会第 75 回年次学術講演会 VI-288, 2020.
- 2) 勝村玲音, 梅田崇之, 安藤慎吾, 島村潤, 和田雅樹, 島原広季, 相原貴明: マンホール内部点検自動化のための深層学習を用いた不良箇所検出手法の検討, The 34th Annual Conference of the Japanese Society for Artificial Intelligence, 4L2-GS-13-02, 2020.